07 | RDD常用算子（二）：Spark如何实现数据聚合？

2021-09-24 吴磊

《零基础入门Spark》 课程介绍 >

讲述：吴磊
时长 18:42 大小 17.13M

你好，我是吴磊。

积累了一定的理论基础之后，今天我们继续来学习 RDD 常用算子。在RDD 常用算子（一）那一讲，我们讲了四个算子 map、mapPartitions、flatMap 和 filter，同时留了这样一道思考题：“这些算子之间，有哪些共同点？”

今天我们就来揭晓答案。首先，在功能方面，这 4 个算子都用于 RDD 内部的数据转换，而学习过 Shuffle 的工作原理之后，我们不难发现，这 4 个算子当中，没有任何一个算子，会引入 Shuffle 计算。

而今天我们要学习的几个算子则恰恰相反，它们都会引入繁重的 Shuffle 计算。这些算子分别是 groupByKey、reduceByKey、aggregateByKey 和 sortByKey，也就是表格中加

粗的部分。

我们知道，在数据分析场景中，典型的计算类型分别是分组、聚合和排序。而 groupByKey、reduceByKey、aggregateByKey 和 sortByKey 这些算子的功能，恰恰就是用来实现分组、聚合和排序的计算逻辑。

算子类型	适用范围	算子用途	算子集合
Transformations	任意RDD	RDD内数据转换	map mapPartitions mapPartitionsWithIndex flatMap filter
	Paired RDD	RDD内数据聚合	groupByKey sortByKey reduceByKey aggregateByKey
	任意RDD	RDD间数据整合	union intersection join cogroup cartesian
	任意RDD	数据整理	sample distinct
	任意RDD	数据分布	coalesce repartition repartitionAndSortWithinPartitions
Actions	任意RDD	数据收集	collect first take takeSample takeOrdered
	任意RDD	数据持久化	saveAsTextFile saveAsSequenceFile saveAsObjectFile
	任意RDD	数据遍历	foreach

极客时间

RDD算子分类表

尽管这些算子看上去相比其他算子的适用范围更窄，也就是它们只能作用（Apply）在 Paired RDD 之上，所谓 Paired RDD，它指的是元素类型为（Key，Value）键值对的 RDD。

但是在功能方面，可以说，它们承担了数据分析场景中的大部分职责。因此，掌握这些算子的用法，是我们能够游刃有余地开发数据分析应用的重要基础。那么接下来，我们就通过一些实例，来熟悉并学习这些算子的用法。

我们先来说说 groupByKey，坦白地说，相比后面的 3 个算子，groupByKey 在我们日常开发中的“出镜率”并不高。之所以要先介绍它，主要是为后续的 reduceByKey 和 aggregateByKey 这两个重要算子做铺垫。

groupByKey：分组收集

groupByKey 的字面意思是“按照 Key 做分组”，但实际上，groupByKey 算子包含两步，即**分组**和**收集**。

具体来说，对于元素类型为（Key，Value）键值对的 Paired RDD，groupByKey 的功能就是对 Key 值相同的元素做分组，然后把相应的 Value 值，以集合的形式收集到一起。换句话说，groupByKey 会把 RDD 的类型，由 RDD[(Key, Value)]转换为 RDD[(Key, Value 集合)]。

这么说比较抽象，我们还是用一个小例子来说明 groupByKey 的用法。还是我们熟知的 Word Count，对于分词后的一个个单词，假设我们不再统计其计数，而仅仅是把相同的单词收集到一起，那么我们该怎么做呢？按照老规矩，咱们还是先来给出代码实现：

复制代码

```
import org.apache.spark.rdd.RDD

// 以行为单位做分词
val cleanWordRDD: RDD[String] = _ // 完整代码请参考第一讲的Word Count
// 把普通RDD映射为Paired RDD
val kvRDD: RDD[(String, String)] = cleanWordRDD.map(word => (word, word))

// 按照单词做分组收集
val words: RDD[(String, Iterable[String])] = kvRDD.groupByKey()
```

结合前面的代码可以看到，相比之前的 Word Count，我们仅需做两个微小的改动，即可实现新的计算逻辑。第一个改动，是把 map 算子的映射函数 f，由原来的 word => （word，1）变更为 word => （word，word），这么做的效果，是把 kvRDD 元素的 Key 和 Value 都变成了单词。

紧接着，第二个改动，我们用 groupByKey 替换了原先的 reduceByKey。相比 reduceByKey，groupByKey 的用法要简明得多。groupByKey 是无参函数，要实现对 Paired RDD 的分组、收集，我们仅需在 RDD 之上调用 groupByKey() 即可。

尽管 groupByKey 的用法非常简单，但它的计算过程值得我们特别关注，下面我用一张示意图来讲解上述代码的计算过程，从而让你更加直观地感受 groupByKey 可能存在的性能隐患。

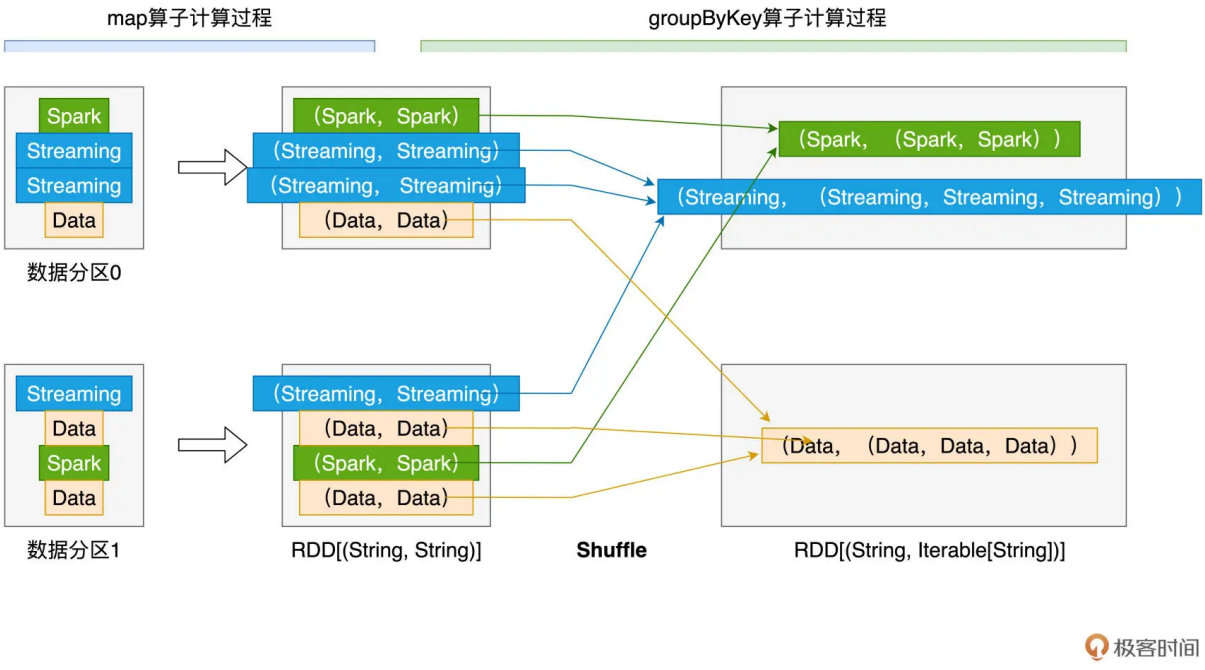

groupByKey计算过程

从图上可以看出，为了完成分组收集，对于 Key 值相同、但分散在不同数据分区的原始数据记录，Spark 需要通过 Shuffle 操作，跨节点、跨进程地把它们分发到相同的数据分区。我们之前在第 6 讲中说了，**Shuffle 是资源密集型计算**，对于动辄上百万、甚至上亿条数据记录的 RDD 来说，这样的 Shuffle 计算会产生大量的磁盘 I/O 与网络 I/O 开销，从而严重影响作业的执行性能。

虽然 groupByKey 的执行效率较差，不过好在它在应用开发中的“出镜率”并不高。原因很简单，在数据分析领域中，分组收集的使用场景很少，而分组聚合才是统计分析的刚需。

为了满足分组聚合多样化的计算需要，Spark 提供了 3 种 RDD 算子，允许开发者灵活地实现计算逻辑，它们分别是 reduceByKey、aggregateByKey 和 combineByKey。

reduceByKey 我们并不陌生，第一讲的 Word Count 实现就用到了这个算子，aggregateByKey 是 reduceByKey 的“升级版”，相比 reduceByKey，aggregateByKey 用法更加灵活，支持的功能也更加完备。

接下来，我们先来回顾 reduceByKey，然后再对 aggregateByKey 进行展开。相比 aggregateByKey，combineByKey 仅在初始化方式上有所不同，因此，我把它留给你作为课后作业去探索。

reduceByKey：分组聚合

reduceByKey 的字面含义是“按照 Key 值做聚合”，它的计算逻辑，就是根据聚合函数 f 给出的算法，把 Key 值相同的多个元素，聚合成一个元素。

在第 1 讲Word Count 的实现中，我们使用了 reduceByKey 来实现分组计数：

复制代码

```
// 把RDD元素转换为（Key，Value）的形式
val kvRDD: RDD[(String, Int)] = cleanWordRDD.map(word => (word, 1))

// 按照单词做分组计数
val wordCounts: RDD[(String, Int)] = kvRDD.reduceByKey((x: Int, y: Int) => x +
```

重温上面的这段代码，你有没有觉得 reduceByKey 与之前讲过的 map、filter 这些算子有一些相似的地方？没错，给定处理函数 f，它们的用法都是“算子 (f)”。只不过**对于 map 来说，我们把 f 称作是映射函数，对 filter 来说，我们把 f 称作判定函数，而对于 reduceByKey，我们把 f 叫作聚合函数。**

在上面的代码示例中，reduceByKey 的聚合函数是匿名函数：(x, y) => x + y。与 map、filter 等算子的用法一样，你也可以明确地定义带名函数 f，然后再用 reduceByKey(f) 的

方式实现同样的计算逻辑。

需要强调的是，给定 RDD[(Key 类型，Value 类型)]，聚合函数 f 的类型，必须是（Value 类型，Value 类型） => （Value 类型）。换句话说，函数 f 的形参，必须是两个数值，且数值的类型必须与 Value 的类型相同，而 f 的返回值，也必须是 Value 类型的数值。

咱们不妨再举一个小例子，让你加深对于 reduceByKey 算子的理解。

接下来，我们把 Word Count 的计算逻辑，改为随机赋值、提取同一个 Key 的最大值。也就是在 kvRDD 的生成过程中，我们不再使用映射函数 word => (word, 1)，而是改为 word => (word, 随机数)，然后再使用 reduceByKey 算子来计算同一个 word 当中最大的那个随机数。

你可以先停下来，花点时间想一想这个逻辑该怎么实现，然后再来参考下面的代码：

复制代码

```
import scala.util.Random._

// 把RDD元素转换为（Key，Value）的形式
val kvRDD: RDD[(String, Int)] = cleanWordRDD.map(word => (word, nextInt(100)))

// 显示定义提取最大值的聚合函数f
def f(x: Int, y: Int): Int = {
return math.max(x, y)
}

// 按照单词提取最大值
val wordCounts: RDD[(String, Int)] = kvRDD.reduceByKey(f)
```

观察上面的代码片段，不难发现，reduceByKey 算子的用法还是比较简单的，只需要先定义好聚合函数 f，然后把它传给 reduceByKey 算子就行了。那么在运行时，上述代码的计算又是怎样的一个过程呢？

我把 reduceByKey 的计算过程抽象成了下图：

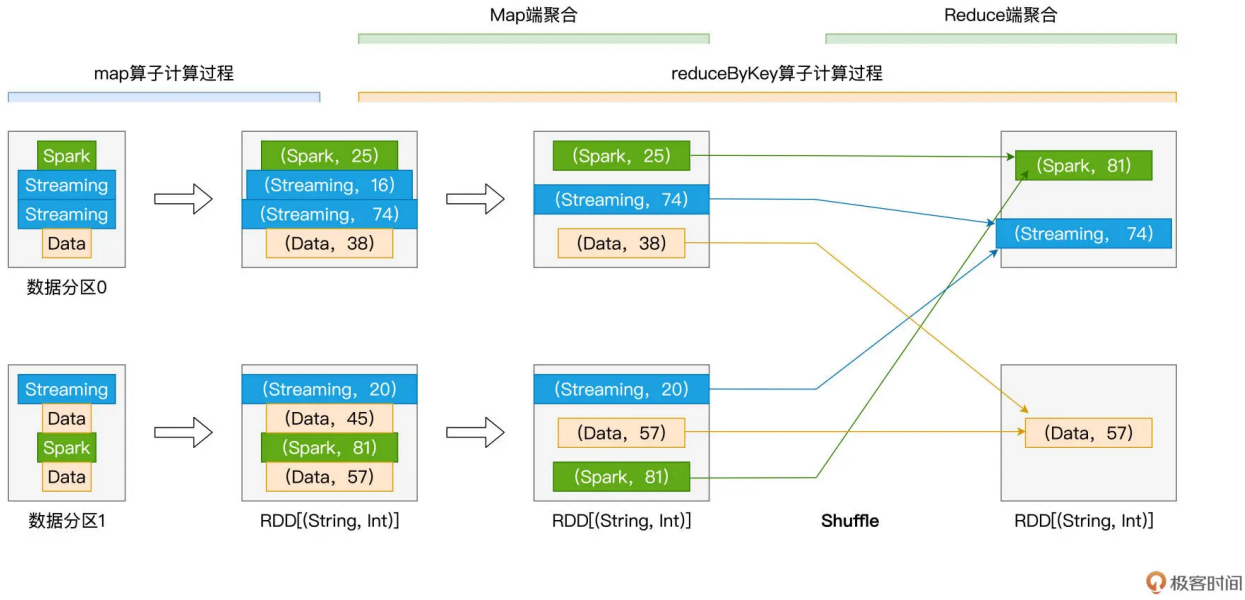

reduceByKey计算过程

从图中你可以看出来，尽管 reduceByKey 也会引入 Shuffle，但相比 groupByKey 以全量原始数据记录的方式消耗磁盘与网络，reduceByKey 在落盘与分发之前，会先在 Shuffle 的 Map 阶段做初步的聚合计算。

比如，在数据分区 0 的处理中，在 Map 阶段，reduceByKey 把 Key 同为 Streaming 的两条数据记录聚合为一条，聚合逻辑就是由函数 f 定义的、取两者之间 Value 较大的数据记录，这个过程我们称之为“**Map 端聚合**”。相应地，数据经由网络分发之后，在 Reduce 阶段完成的计算，我们称之为“**Reduce 端聚合**”。

你可能会说：“做了 Map 聚合又能怎样呢？相比 groupByKey，reduceByKey 带来的性能收益并不算明显呀！”确实，就上面的示意图来说，我们很难感受到 reduceByKey 带来的性能收益。不过，量变引起质变，在工业级的海量数据下，相比 groupByKey，reduceByKey 通过在 Map 端大幅削减需要落盘与分发的数据量，往往能将执行效率提升至少一倍。

应该说，对于大多数分组 & 聚合的计算需求来说，只要设计合适的聚合函数 f，你都可以使用 reduceByKey 来实现计算逻辑。不过，术业有专攻，reduceByKey 算子的局限性，**在于其 Map 阶段与 Reduce 阶段的计算逻辑必须保持一致，这个计算逻辑统一由聚合函数 f 定义**。当一种计算场景需要在两个阶段执行不同计算逻辑的时候，reduceByKey 就爱莫能助了。

比方说，还是第 1 讲的 Word Count，我们想对单词计数的计算逻辑做如下调整：

在 Map 阶段，以数据分区为单位，计算单词的加和；

而在 Reduce 阶段，对于同样的单词，取加和最大的那个数值。

显然，Map 阶段的计算逻辑是 sum，而 Reduce 阶段的计算逻辑是 max。对于这样的业务需求，reduceByKey 已无用武之地，这个时候，就轮到 aggregateByKey 这个算子闪亮登场了。

aggregateByKey：更加灵活的聚合算子

老规矩，算子的介绍还是从用法开始。相比其他算子，aggregateByKey 算子的参数比较多。要在 Paired RDD 之上调用 aggregateByKey，你需要提供一个初始值，一个 Map 端聚合函数 f1，以及一个 Reduce 端聚合函数 f2，aggregateByKey 的调用形式如下所示：

复制代码

```
val rdd: RDD[(Key类型，Value类型)] = _
rdd.aggregateByKey(初始值)(f1, f2)
```

初始值可以是任意数值或是字符串，而聚合函数我们也不陌生，它们都是带有两个形参和一个输出结果的普通函数。就这 3 个参数来说，比较伤脑筋的，是它们之间的类型需要保持一致，具体来说：

初始值类型，必须与 f2 的结果类型保持一致；

f1 的形参类型，必须与 Paired RDD 的 Value 类型保持一致；

f2 的形参类型，必须与 f1 的结果类型保持一致。

不同类型之间的一致性描述起来比较拗口，咱们不妨结合示意图来加深理解：

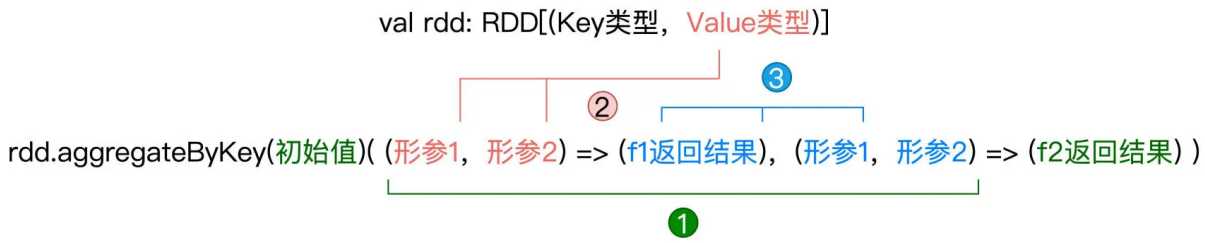

极客时间

aggregateByKey参数之间的类型一致性

熟悉了 aggregateByKey 的用法之后，接下来，我们用 aggregateByKey 这个算子来实现刚刚提到的“先加和，再取最大值”的计算逻辑，代码实现如下所示：

复制代码

```
// 把RDD元素转换为（Key，Value）的形式
val kvRDD: RDD[(String, Int)] = cleanWordRDD.map(word => (word, 1))

// 显示定义Map阶段聚合函数f1
def f1(x: Int, y: Int): Int = {
return x + y
}

// 显示定义Reduce阶段聚合函数f2
def f2(x: Int, y: Int): Int = {
return math.max(x, y)
}

// 调用aggregateByKey，实现先加和、再求最大值
val wordCounts: RDD[(String, Int)] = kvRDD.aggregateByKey(0) (f1, f2)
```

怎么样？是不是很简单？结合计算逻辑的需要，我们只需要提前定义好两个聚合函数，同时保证参数之间的类型一致性，然后把初始值、聚合函数传入 aggregateByKey 算子即可。按照惯例，我们还是通过 aggregateByKey 在运行时的计算过程，来帮你深入理解算子的工作原理：

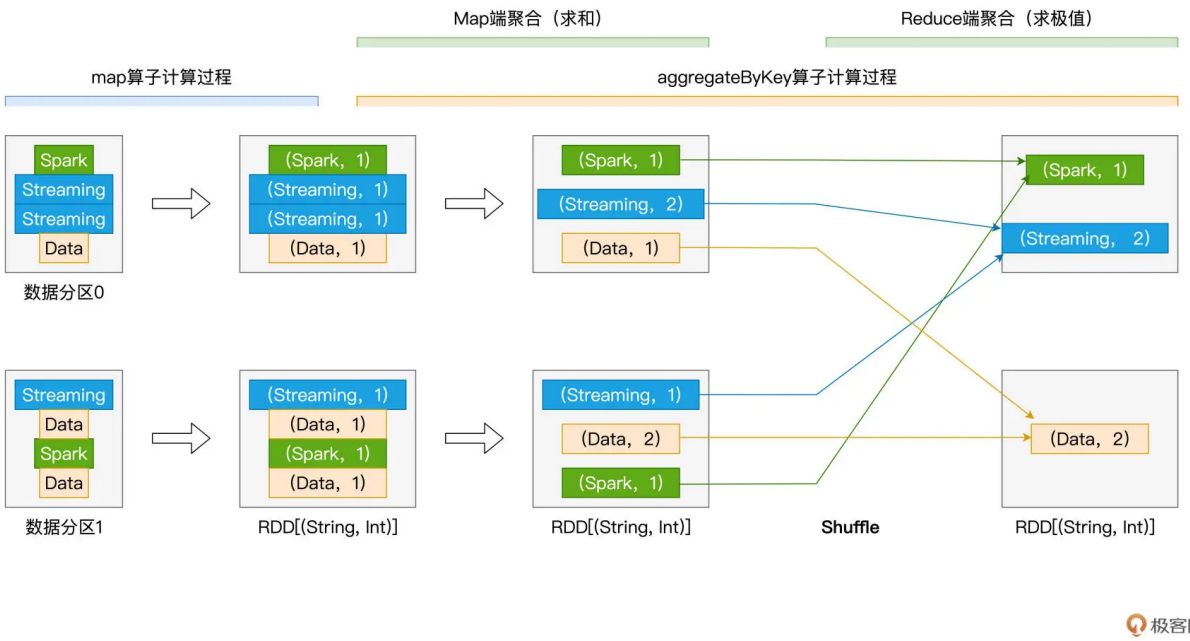

reduceByKey计算过程

不难发现，在运行时，与 reduceByKey 相比，aggregateByKey 的执行过程并没有什么两样，最主要的区别，还是 Map 端聚合与 Reduce 端聚合的计算逻辑是否一致。值得一提的是，与 reduceByKey 一样，aggregateByKey 也可以通过 Map 端的初步聚合来大幅削减数据量，在降低磁盘与网络开销的同时，提升 Shuffle 环节的执行性能。

sortByKey：排序

在这一讲的最后，我们再来说说 sortByKey 这个算子，顾名思义，它的功能是“按照 Key 进行排序”。给定包含（Key，Value）键值对的 Paired RDD，sortByKey 会以 Key 为准对 RDD 做排序。算子的用法比较简单，只需在 RDD 之上调用 sortByKey() 即可：

复制代码

```
val rdd: RDD[(Key类型，Value类型)] = _
rdd.sortByKey()
```

在默认的情况下，sortByKey 按照 Key 值的升序（Ascending）对 RDD 进行排序，如果想按照降序（Descending）来排序的话，你需要给 sortByKey 传入 false。总结下来，关于排序的规则，你只需要记住如下两条即可：

升序排序：调用 sortByKey()、或者 sortByKey(true)；

降序排序：调用 sortByKey(false)。

重点回顾

今天这一讲，我们介绍了数据分析场景中常用的 4 个算子，它们分别是 groupByKey、reduceByKey、aggregateByKey 和 sortByKey，掌握这些算子的用法与原理，将为你游刃有余地开发数据分析应用打下坚实基础。

关于这些算子，你首先需要了解它们之间的共性。**一来，这 4 个算子的作用范围，都是 Paired RDD；二来，在计算的过程中，它们都会引入 Shuffle**。而 Shuffle 往往是 Spark 作业执行效率的瓶颈，因此，在使用这 4 个算子的时候，对于它们可能会带来的性能隐患，我们要做到心中有数。

再者，你需要掌握每一个算子的具体用法与工作原理。groupByKey 是无参算子，你只需在 RDD 之上调用 groupByKey() 即可完成对数据集的分组和收集。但需要特别注意的是，**以全量原始数据记录在集群范围内进行落盘与网络分发，会带来巨大的性能开销。**因此，除非必需，你应当尽量避免使用 groupByKey 算子。

利用聚合函数 f，reduceByKey 可以在 Map 端进行初步聚合，大幅削减需要落盘与分发的数据量，从而在一定程度上能够显著提升 Shuffle 计算的执行效率。对于绝大多数分组 & 聚合的计算需求，只要聚合函数 f 设计得当，reduceByKey 都能实现业务逻辑。reduceByKey 也有其自身的局限性，那就是其 Map 阶段与 Reduce 阶段的计算逻辑必须保持一致。

对于 Map 端聚合与 Reduce 端聚合计算逻辑不一致的情况，aggregateByKey 可以很好地满足这样的计算场景。aggregateByKey 的用法是 aggregateByKey(初始值)(Map 端聚合函数，Reduce 端聚合函数)，对于 aggregateByKey 的 3 个参数，你需要保证它们之间类型的一致性。一旦类型一致性得到满足，你可以通过灵活地定义两个聚合函数，来翻着花样地进行各式各样的数据分析。

最后，对于排序类的计算需求，你可以通过调用 sortByKey 来进行实现。sortByKey 支持两种排序方式，在默认情况下，sortByKey() 按 Key 值的升序进行排序，sortByKey() 与 sortByKey(true) 的效果是一样的。如果想按照降序做排序，你只需要调用 sortByKey(false) 即可。

到此为止，我们一起学习了 RDD 常用算子的前两大类，也就是数据转换和数据聚合。在日常的开发工作中，应该说绝大多数的业务需求，都可以通过这些算子来实现。

因此恭喜你，毫不夸张地说，学习到这里，你的一只脚已经跨入了 Spark 分布式应用开发的大门。不过，我们还不能骄傲，“学会”和“学好”之间还有一定的距离，在接下来的时间里，期待你和我一起继续加油，真正做到吃透 Spark、玩转 Spark！

每课一练

这一讲到这里就要结束了，今天的练习题是这样的：

学习过 reduceByKey 和 aggregateByKey 之后，你能说说它们二者之间的联系吗？你能用 aggregateByKey 来实现 reduceByKey 的功能吗？

欢迎你分享你的答案。如果这一讲对你有帮助，也欢迎你把这一讲分享给自己的朋友，和他一起来讨论一下本讲的练习题，我们下一讲再见。

分享给需要的人，Ta订阅后你可得 20 元现金奖励

赞 3 提建议

© 版权归极客邦科技所有，未经许可不得传播售卖。 页面已增加防盗追踪，如有侵权极客邦将依法追究其法律责任。

上一篇 06 | Shuffle管理：为什么Shuffle是性能瓶颈？

更多学习推荐

精选留言

写留言

> 由作者筛选后的优质留言将会公开显示，欢迎踊跃留言。